




îàÆÄäø
ÆàÄÉêê
æïÄåìøò
æêæÆài é

VISIT...

LANZAROTE
Caliente.COM

МЕТОДЫ ТЕОРИИ СЛОЖНЫХ СИСТЕМ В ЭКОНОМИКЕ И ФИНАНСАХ

Д.А.Дмитриева ^{□□}, Ю.А.Куперин ^{□□}, И.В.Сорока [□] [1] *

[□] Физический факультет, Санкт-Петербургский

[□] государственный университет

[□] Факультет менеджмента, Санкт-Петербургский

[□] государственный университет

[□] Балтийское финансовое агентство

I. Введение

Ключевые концепции традиционных моделей управления капиталом и традиционные аналитические методы анализа финансовых рынков все чаще и чаще наталкиваются на проблемы, не имеющие эффективного решения в рамках устоявшихся парадигм. Это и неудивительно, ведь традиционные, ставшие уже классическими, подходы были разработаны для описания относительно устойчивого, медленно эволюционирующего и не радикально изменяющегося мира, мира – который еще не сильно отклонился от состояния равновесия. По самой своей сути эти методы и подходы не были предназначены для описания и моделирования быстрых изменений, непредсказуемых скачков и сложных взаимодействий отдельных составляющих современного мирового рыночного процесса.

Постепенно стало ясно, что изменения в финансовом мире происходят настолько интенсивно, а их качественные проявления бывают настолько неожиданными, что для анализа и прогнозирования финансовых рынков синтез новых аналитических и вычислительных подходов, берущих свое начало в различных областях человеческих знаний, стал насущной практической необходимостью. Этот синтез был осуществлен в рамках бурно развивающейся в настоящее время междисциплинарной науки – теории сложности. Теория сложности изучает динамические процессы в необратимых многокомпонентных интерактивных адаптивных системах. Она рассматривает причины и механизмы возникновения новых режимов и структур, изучает характерные масштабы и скорости переходных и установившихся процессов, предсказывает вероятные изменения системы и указывает на то, как можно было бы управлять неожиданными динамическими режимами, возникающими в сложных системах. Правила, управляющие сложными адаптивными системами коренным образом отличаются от тех, по которым функционируют равновесные системы, и которые являются основой вышеупомянутых

традиционных классических методов анализа финансовых рынков. Поэтому именно теория сложных систем со своим богатым междисциплинарным арсеналом методов и алгоритмов может стать адекватным инструментом для анализа сложных неравновесных адаптивных динамических процессов, происходящих на современном финансовом рынке.

В теории сложных систем исследуются, главным образом, нелинейные системы с обратной связью, когда информация с выхода системы подается на вход и становится следующим набором входных данных. Безусловно, финансовые рынки нельзя автоматически отнести к таким системам, однако рынки демонстрируют много характерных свойств нелинейных систем с обратной связью. Последние годы ознаменовались повышенным интересом к поиску нелинейных моделей, которые могли бы адекватно воспроизводить сложные паттерны финансовых динамических процессов, поскольку уже стало ясно, что линейный подход к анализу финансовых рынков не позволяет смоделировать сильно нерегулярное поведение, характерное для большинства финансовых активов. Существует несколько конкурирующих подходов, использующих идею нелинейности. Традиционные модели являются стохастическими (ARCH, GARCH и их модификации). Однако те ограничения, которые используются при построении и фитировании модели с целью сделать ее пригодной для практического использования, по сути дела, уничтожает ту уникальную внутреннюю «сложность» которая присуща рассматриваемому динамическому процессу и без которой он становится безликим представителем абстрактных финансовых данных.

В связи с этим, в последнее время интенсивно развивается альтернативный подход к анализу нелинейностей, а именно подход, базирующийся на теории детерминистического хаоса, которая предлагает исчерпывающее объяснение иррегулярному поведению и аномалиям в системах, которые, не являясь по своей природе стохастическими, ведут себя подобным образом. Теория хаоса предлагает совершенно новые концепции и алгоритмы для анализа временных рядов, которые могут привести к более глубокому и полному пониманию отражаемых ими финансовых процессов. Теория динамического хаоса вводит в традиционный язык финансовых аналитиков такие новые в этой сфере понятия как фазовое пространство, аттрактор, ляпуновские экспоненты, горизонт предсказания, энтропии и размерности, фрактальные статистики и информационные циклы и т.д.

При анализе и предсказании сложных финансовых систем в настоящее время нельзя обойтись и без такого мощного инструмента как нейросетевые технологии. Использование нейронных сетей и генетических алгоритмов постепенно становится конкурентоспособным подходом при решении задач предсказания, классификации, моделирования финансовых временных рядов, а также при решении задач оптимизации в области финансового анализа и управления риском.

В настоящей работе мы остановимся лишь на двух аспектах применения теории сложных систем в анализе финансовых рынков: методах хаотической динамики нейросетевых методах.

II. Исследование динамики рынков методами хаотической динамики

Последние годы ознаменовались растущим интересом к поиску моделей нелинейного поведения на финансовых рынках. Это объясняется тем, что нелинейные модели могут улавливать очень сложные паттерны в финансовых данных. В то же время, как теперь уже хорошо осознано, линейный подход не позволяет учесть и проанализировать сильно нерегулярное поведение, которое может демонстрироваться многочисленными финансовыми активами. Чтобы анализировать различные типы нелинейностей, которые могут наблюдаться, в настоящее время существует несколько альтернативных подходов. Традиционные модели являются стохастическими (например, ARCH, GARCH, EGARCH, FIGARCH и т.д. (см., напр.: Mills, 1993; Franses, 1998)). Однако те ограничения, которые накладываются в процессе построения, приводят в конце концов к относительно простым и идентифицируемым моделям, в то время как исходная «сложность» и связанная с ней специфика теряются.

Другой подход к анализу нелинейностей и сложности финансовых данных основан на теории детерминированного хаоса (см., напр.: Kantz, Schreiber, 1997; Schuster, 1984; Peters, 1996). В частности, детерминированный хаос предлагает поразительное объяснение нерегулярного поведения и аномалий в системах, которые не являются стохастическими. Теория хаоса предлагает совершенно новые концепции и алгоритмы для анализа временных рядов, анализа, который может привести к более полному пониманию природы сигналов. Эта теория представляет широкий выбор мощных методов, включая восстановление аттрактора в лаговом фазовом пространстве, вычисление показателей Ляпунова, обобщенных размерностей

и энтропий, нелинейное предсказание и редукцию шумов, а также статистические тесты на нелинейность.

В настоящем разделе мы представим результаты применения лишь одного теста из богатого арсенала методов, позволяющих определить наличие детерминированной хаотической компоненты в динамике финансовых инструментов. Для анализа мы выбрали фьючерсные контракты на британский фунт, швейцарский франк, канадский доллар, евродоллар, немецкую марку и индекс Standards&Poors 500. Мы использовали временные ряды дневных доходностей за период 04/01/95 – 31/08/99. Данные взяты из Free Historical Futures Data, поставляемых Turtle Trader Company.

Главная идея применения методов хаотической динамики к анализу временных рядов состоит в том, что основная структура хаотической системы, содержащая в себе всю информацию о системе, а именно аттрактор динамической системы (то есть подмножество фазового пространства, притягивающее траектории в пределе бесконечного времени), может быть восстановлена через измерение только одной наблюдаемой этой динамической системы, фиксированной как временной ряд. Согласно методу Грасбергера и Прокаччи (см., напр.: Grassberger и Procaccia, 1983) процедура реконструкции фазового пространства и восстановление хаотического аттрактора системы при динамическом анализе временного ряда сводится к построению так называемого лагового пространства. Предположим, что данный временной ряд порожден некоторой хаотической динамической системой. Предположим, что m - наименьшая размерность фазового пространства, в которое можно погрузить реальный аттрактор динамической системы. Тогда посредством временного ряда X_n , $n = 1, 2, \dots, N$, «восстановленный» аттрактор формируется из векторов $Y_n = (X_n, X_{n-1}, \dots, X_{n-(m-1)})$ в m - мерном пространстве, называемом лаговым пространством изучаемого временного ряда. Если временной ряд, действительно, является наблюдаемой "проекцией" стоящей за ним хаотической динамической системы, то согласно теореме Такенса (см., например: Kantz, Schreiber, 1997), реальный аттрактор динамической системы и "аттрактор", восстановленный в лаговом пространстве по временному ряду согласно указанному выше правилу, при адекватном подборе размерности вложения m являются топологически эквивалентными и обладают одинаковыми обобщенными фрактальными размерностями, ляпуновскими показателями и другими численными характеристиками. Если же анализируемый временной ряд

является реализацией случайного процесса, то восстановленный "псевдоаттрактор" представляет собой бесструктурное облако точек, которое при последовательном бесконечном увеличении размерности вложения лагового пространства m , подобно газу, заполняет весь предоставленный ему объем.

Один из тестов, применяемых на практике для выяснения наличия хаотической детерминированности в изучаемом ряде финансовых данных, состоит в изучении свойств корреляционной суммы $C_m(R)$ и поведения корреляционной размерности $D(m)$ в зависимости от размерности вложения m . Корреляционная сумма $C_m(R)$ - это вероятность того, что пара точек на восстановленном аттракторе в m - мерном лаговом пространстве находится в пределах расстояния R друг друга. Если график функции $\log C_m(R)$ относительно $\log R$ имеет отчетливо выраженный линейный участок, это указывает на самоподобную геометрию аттрактора (см., например: Kantz, Schreiber, 1997; Peters, 1996), что, в свою очередь, говорит о хаотической детерминированности финансового инструмента. Корреляционная размерность вычисляется как средний наклон указанного выше графика, а ошибка вычисления берется как половина разницы максимального и минимального наклона. При увеличении размерности вложения корреляционная размерность увеличивается. Однако для хаотических данных корреляционная размерность будет в конечном счете насыщаться при ее истинном значении (см. рис.1, примеры *chaos.dat* и *henon.dat*). Для случайных данных такого насыщения не наблюдается и корреляционная размерность растет монотонно. Чтобы объяснить такое поведение корреляционной размерности заметим, что в рамках метода Грасбергера и Прокаччи (см., напр.: Grassberger и Procaccia, 1983) корреляционная размерность для реальных хаотических систем является хорошим приближением для фрактальной размерности странного аттрактора. Фрактал, вложенный в пространство с более высокой размерностью, сохраняет свою истинную размерность из-за нелинейных корреляций между точками. Поэтому для детерминированного хаотического временного ряда корреляционная размерность сходится к ее истинному значению. В то же самое время для случайной последовательности, как уже отмечалось выше, точки восстановленного "псевдоаттрактора" образуют бесструктурное облако в лаговом пространстве вне зависимости от его размерности.

Как правило, хаотические детерминированные системы маломерны. Эффект добавления шума приводит к увеличению

корреляционной размерности. Это можно наблюдать на рис.1 , сравнивая результаты для временного ряда, порожденного хаотическим отображением Хенона (henon.dat) и для тех же самых данных после добавления шума (henoise.dat). Корреляционная размерность увеличилась от 1.23 до приблизительно 4, однако ее насыщение с увеличением размерности вложения происходит так же, как это имеет место для истинно хаотических данных. Обратим внимание, что корреляционная размерность больше, чем пять подразумевает, по существу, случайные данные (см. рис.1, пример броуновского движения).

Рис.1. Зависимость корреляционной размерности от размерности вложения для тестовых примеров

Для вычисления корреляционной размерности аттрактора динамической системы, которая, возможно, "управляет" динамикой данного финансового инструмента следует строить лаговое пространство по детрендированным логарифмам цен (в нашем случае фьючерсных цен). Поэтому исходные ряды доходностей по анализируемым фьючерсам были соответствующим образом преобразованы. Результаты вычисления корреляционных размерностей в зависимости от размерности лагового пространства представлены на рис.2. Среди всех рядов мы выделим ряды, которые условно можно назвать зашумленными хаотическими рядами. Для таких рядов корреляционные размерности должны в конечном счете насыщаться при некотором значении, которое является меньше 5 в пределах вычислительной ошибки. Кроме того для таких рядов ошибка вычисления при каждом значении размерности вложения должна быть маленький (эти ошибки на рис.2 показаны вертикальными линиями). Большая ошибка подразумевала бы, что график логарифма корреляционной суммы относительно логарифмов расстояния не имеет отчетливого линейного участка, и понятие корреляционной размерности аттрактора (в этом случае "псевдоаттрактора") для таких наборов данных бессмысленно из-за случайного характера данных.

Из всех проанализированных рядов к зашумленным хаотическим рядам, как следует из рис.2, мы можем отнести

лишь фьючерс на евродоллар, для которого корреляционная размерность оказалась равной 3.7(0.3. В динамике остальных фьючерсов хаотическая компонента (если таковая имеется) сильно подавлена уровнем шума и, как для ее выделения, так и для доказательства факта отсутствия таковой, требуется проведения дополнительных тестов из арсенала методов нелинейного хаотического анализа временных рядов. В настоящем исследовании мы также вычислили методом Вольфа (Wolf, 1985) значение наибольшего показателя Ляпунова для фьючерса на евродоллар. Он оказался равен 0.27(0.03. Как хорошо известно, наличие положительного ляпуновского показателя отражает чувствительную зависимость динамической системы от начальных данных, что является одним из главных признаков детерминированного хаоса. Именно это свойство ответственно за нерегулярное поведение детерминированных хаотических систем, которое часто по "внешним" проявлениям интерпретируется как случайное, на самом деле отнюдь не являясь таковым. С ляпуновским показателем непосредственно связан горизонт предсказуемости хаотической системы: за время обратно пропорциональное показателю Ляпунова система полностью теряет информацию о своем начальном состоянии. Таким образом, прогноз динамики хаотической системы на временах больших горизонта предсказуемости в принципе невозможен.

Рис.2. Зависимость корреляционной размерности от размерности вложения

(H_TREND.DAT – фьючерс на британский фунт

B_TREND.DAT - фьючерс на индекс S&P500

I_TREND.DAT - фьючерс на швейцарский франк

J_TREND.DAT - фьючерс на канадский доллар

S_TREND.DAT - фьючерс на евродоллар

V_TREND.DAT - фьючерс на немецкую марку)

III. Исследование динамики финансовых рынков нейросетевыми методами

В настоящем разделе рассматриваются динамические процессы в трех секторах финансовых рынков – валютном, денежном и капитальном.

Новизна проблематики состоит в анализе финансовой динамики нейросетевыми методами в комбинации с подходами, развитыми в эконофизике. Нейросетевой подход к анализу и прогнозированию финансовых временных рядов, использованный в настоящем разделе, основывается на парадигме теории сложных систем и ее применимости к анализу финансовых рынков [см.: Mantegna, Stenley, 2000].

Использованный нами подход является оригинальным и отличается от подходов других авторов [см.: Baestaens, .Van Den Bergh, Wood, 1994; Ежов , Шумский , 1998] в следующих аспектах. При выборе архитектуры сети и способа прогнозирования мы проводили глубокую предварительную обработку данных, используя методы теории сложных систем: фрактальный и мультифрактальный анализ [см., напр. Feder, 1988; Mandelbrot, 1988, 1995, 1997, 1998; Bacry, 2000; Calvet, 1997; Cont, 1997, Fisher, 1997], вейвлет-анализ [см., напр.: Davis, 1994; Torrence, 1998], методы нелинейной и хаотической динамики [см., напр. Arthur, LeBaron, Holland, Palmer, Tayler, 1997; . LeBaron, 1997, LeBaron, Brock, Dechert, Scheinkman, 1996; LeBaron, 1994; Peters, 1996]. В настоящей работе мы не описываем этапов и методов этой предварительной обработки данных. Однако предварительный анализ позволил оптимизировать параметры нейросети, определить горизонт прогноза и провести сравнение качества предсказаний для временных рядов из различных секторов финансового рынка. В частности, для сравнения качества предсказания различных финансовых рядов нейросетью одной и той же архитектуры мы нормировали исходные данные к одинаковой дисперсии.

1. Постановка задачи нейросетевого анализа

Рассмотрим динамические процессы на валютном, денежном, капитальном рынках в краткосрочные периоды, прогнозируя дневную динамику методами нейронных сетей [Baestaens, Van Den Bergh, Wood, 1994; .Hecht-Nielsen, 1990; Kean ., 1992; Casseti , 1993; Kuo , Principe ., deVries , 1992].

Анализируемые в настоящем разделе финансовые инструменты– это фьючерсы:

на курс доллар США - немецкая марка (обозначен как DM);

на ставку процента ЛИБОР по евродолларам (ED);

на фондовый американский индекс Стэндарт-энд-Пурс S&P500 (SP)

Данные по всем фьючерсам за период 04/01/95-31/08/1999 гг. взяты из Free Historical Futures Data, поставляемых Turtle Trader Company.

Цель данного исследования - показать, что нейронные сети способны находить скрытые динамические закономерности в данных, на которых они обучаются, и (на этой основе) прогнозировать динамику, статистически оценивая результаты прогноза. Следует отметить, что хорошо обученная нейронная сеть часто находит в данных закономерности, не доступные человеку-аналитику.

Отметим две особенности нейросетевого анализа. Если в данных, на которых обучалась нейросеть, не отражены ценовые изменения, обусловленные экзогенными факторами (начало, окончание войн, реформа валютной системы, неожиданные результаты выборов президента, последствия террористических атак), то нейросеть не сможет предсказать похожие ценовые изменения в будущем. В то же время нейронные сети эффективны для предсказаний финансовых крахов, паник, если они порождены эндогенными факторами (искаженное распространение информации, рост курсов из-за больших покупок, падения из-за больших продаж, изменение ликвидности рынков, нелинейность корректировки курсов).

2. Методы нейросетевого анализа и прогнозов

Нейронные сети – это системы искусственного интеллекта, способные к самообучению в процессе решения задач [Baestaens, Van Den Bergh, Wood, 1994; .Hecht-Nielsen, 1990; Kean ., 1992; Cassetti , 1993; Kuo , Principe , deVries , 1992; Giles ., Lawrence , Tsoi ., 1997; Demuth , Beale , 1997; Ежов , Шумский , 1998].

Обучение сводится к обработке сетью множества примеров, состоящих из:

набора пар входов и выходов (обучение с учителем) ;

набора только входов (обучение без учителя).

В первом случае сеть по заданным входам генерирует свои выходы и сравнивает последние с выходами из обучающего набора. Для максимизации выходов, попадающих в допустимый интервал отклонения от обучающих, нейронная сеть модифицирует интенсивности связей между нейронами, из которых она построена, и таким образом самообучается.

Прогонка обучающих примеров проводится, пока не достигается желаемая точность совпадения реальных и обучающих выходов. С этого момента нейросеть считается обученной, и может быть применена к обработке данных, похожих на обучающие, но не совпадающие с ними.

Модель любой нейронной сети состоит, таким образом, :
из элементов, обрабатывающих сигналы (нейронов);
связей между нейронами;
обучающих схем или правил.

Каждый нейрон сети обладает собственным весом (положительным, отрицательным) и так называемой функцией активации. Нейрон обрабатывает входные сигналы, суммируя входы с весами и трансформируя полученный результат в выходной сигнал с помощью функции активации (линейной, нелинейной, стохастической). Нейроны сети взаимодействуют друг с другом в зависимости от топологии связей. Последние бывают полными (каждый с каждым), частичными (противоположность полной связи), с петлями обратных связей, без таковых. В каждой задаче требуется свой выбор архитектуры сети. Наличие обратных связей влияет на обучаемость сети (улучшая ее), тогда как степень внутренних связей определяет параллелизм вычислений. Когда нейросети стали популярны, они состояли из одного или двух слоев нейронов – входного и/или выходного. Круг задач, решаемый такими сетями, был ограничен. Современные многослойные нейросети мощнее, в частности, из-за того, что они формируют внутреннее представление задачи в так называемых скрытых слоях. Иерархические сети используются для распознавания образов. При этом внутренние слои играют роль «детекторов выученных свойств», поскольку активность паттернов в скрытых слоях есть кодирование того, что сеть «думает» о свойствах, содержащихся во входах.

Наиболее популярный обучающий алгоритм – это обратное распространение ошибки, состоящее из взаимосвязанных процессов. В прямом процессе входной сигнал проходит через сеть, генерируя определенный выход. В обратном процессе ошибка (разница между желаемым и полученным выходом) передается от выходных слоев к входным с одновременной модификацией связей нейронов так, чтобы (при последующем прогоне информации через сеть) ошибка на выходном слое уменьшилась. В этом состоит обучение сети.

Опишем методику нейросетевого прогнозирования рассматриваемых в статье финансовых инструментов.

Успех нейросетевых предсказаний зависит от типа информации, подаваемой на вход, и от того, какие характеристики выходных данных значимы в задаче прогноза. В построенной сети на один из входов подавались значения дневных доходностей анализируемых финансовых инструментов, выраженные следующим образом: изменению 1,5 % соответствовало

значение 1,5. На другой вход подавались дневные доходности, усредненные за последние 5 дней. Использование сглаживающих средних было необходимо в связи с высокой шумовой компонентой в данных. Выходом сети было сдвинутое на 1 день назад значение 5-дневного скользящего среднего. Таким образом, сеть давала прогноз сглаженного 5-дневного среднего на один день в будущее. Из всевозможных конфигураций нейросетей была выбрана рекуррентная нейросеть с обратной связью от скрытого слоя ко входному (см. рис.3).

Рис. 3. Архитектура нейронной сети Элмана-Джордана, использованной для прогноза.

Этот тип сетей с обучением методом обратного распространения ошибки успешно использовался для предсказания финансовых рынков, поскольку именно рекуррентная сеть выучивает закономерности в последовательности величин, что необходимо для работы с временными рядами. Недостатком такой сети является длительное время обучения. Послойные сети, обучаемые этим методом, на каждый идентичный входной паттерн отвечают одним и тем же паттерном на выходе. Рекуррентные сети могут отвечать на один и тот же входной паттерн по-разному, в зависимости от того, какой паттерн был предшествовавшим. Таким образом, для них существенна последовательность обучающих примеров. Иными словами, рекуррентные сети могут быть обучены так же, как стандартные сети с обратным распространением ошибки, однако обучающие примеры должны быть упорядочены и не могут предъявляться сети в случайно выбранном порядке. Существенная разница с послойными сетями заключается в наличии у сети Элмана-Джордана дополнительного блока, хранящего информацию о предыдущих входах. Он может быть интерпретирован как блок долговременной памяти нейросети.

Нейроны скрытого слоя сети Элмана-Джордана имеют логистическую функцию активации $f(x)=1/(1+\exp(-x))$, тогда как нейроны выходного слоя обладают линейной функцией активации. Такая комбинация позволяет аппроксимировать любую функцию с конечным числом разрывов с заданной точностью. Мы использовали симметричную логистическую функцию активации $f(x)=(2/(1+\exp(-x)))-1$. Это не влияло на предсказательные свойства сети, но приводило к более быстрой сходимости алгоритма обучения для данного типа временных

рядов. По сути, единственным требованием к сети было достаточное число нейронов в скрытом слое, поскольку их число должно возрастать пропорционально сложности анализируемых данных (сложность данных оказалась такой, что удалось ограничиться 100 нейронами в скрытом слое).

Наиболее трудным в использовании нейросетей является выбор момента остановки обучения. Если сеть обучать недолго, то она не выучит выборку обучающих примеров. Если сеть обучать слишком долго, то она выучит примеры с шумами со сколь угодно высокой точностью, но окажется неспособной обобщать примеры (т. е. будет действовать схожим образом на данных, не входивших в обучающее множество). Для преодоления этой трудности мы использовали процедуру калибровки с тем, чтобы оптимизировать сеть, применяя ее к независимому тестовому множеству примеров в процессе обучения. Калибровка позволяет найти оптимум нейросети на тестовом множестве, означая способность сети к обобщению, т. е. получению хороших результатов на новых данных. Это достигается вычислением среднеквадратичной ошибки между реальными и предсказанными выходами. Мы использовали среднеквадратичную ошибку как стандартную статистическую меру качества фитирования.

3. Нейросетевые прогнозы доходностей

Опишем необходимые технические детали, связанные с обучением и прогнозом использованной нами нейросети на описанных выше данных.

Из каждого временного ряда выделялось 3 подмножества: тренерочное (примеры, на которых обучалась сеть) – первые 900 значений для всех фьючерсов;

тестовое (примеры, которые служили для предотвращения переучивания сети или калибровки) – значения фьючерсных рядов с 901 по 1100;

рабочее (примеры, которые сеть не видела) – последние 200 значений для фьючерсных временных рядов.

Результаты предсказания нейросетью рабочего множества всех проанализированных временных финансовых рядов приведены на рис. 4а-с.

Рис. 4а. Нейросетевые предсказания 5-дневных сглаженных относительных изменений котировки фьючерса на марку ФРГ – DM

(верхний рисунок – графики фактического и предсказанного нейросетью изменений, выраженных в процентах; рисунок в середине – совпадение знака предсказания на каждый день;

нижний рисунок – модуль ошибки предсказания, выраженный в процентах. По горизонтальной оси отложены номера отсчетов (дней).)

Рис. 4б. Нейросетевые предсказания 5-дневных сглаженных относительных изменений котировки фьючерса на евродоллар – ED

(верхний рисунок – графики фактического и предсказанного нейросетью изменений, выраженных в процентах; рисунок в середине – совпадение знака предсказания на каждый день; нижний рисунок – модуль ошибки предсказания, выраженный в процентах. По горизонтальной оси отложены номера отсчетов (дней).)

Рис. 4с. Нейросетевые предсказания на рабочем множестве 5-дневных сглаженных относительных изменений котировки фьючерса на биржевой индекс S&P500 – SP

[верхний рисунок – графики фактического и предсказанного нейросетью изменений, выраженных в процентах; рисунок в середине – совпадение знака предсказания на каждый день; нижний рисунок – модуль ошибки предсказания, выраженных в процентах. По горизонтальной оси отложены номера отсчетов (дней)].

Эффективность предсказаний нейросети проверялась сравнением фактического значения и предсказанного нейросетью.

Критериями качества предсказания служили следующие параметры:

Число эпох и время обучения – показатели, как долго сеть способна улучшать предсказания на тестовом множестве. Под эпохой обучения понимают однократное предъявление сети набора обучающих примеров. Число эпох и время обучения меняются в зависимости от заданных темпа обучения и момента, устанавливаемых из желаемой точности предсказания. Чем меньше их значения, тем более точен результат и тем дольше обучается нейросеть. В использованной сети оба параметра имели значение 0,003.

Коэффициент Q сравнивает точность нейросетевой модели с точностью модели, в которой предсказания одинаковы и совпадают со средним значением всех примеров. Для последней модели коэффициент Q равен нулю. Самый лучший результат достигается, если Q принимает значение 1, для очень хорошего результата Q близок к 1, для очень плохого - в окрестности 0. Если нейросетевое предсказание оказывается хуже, чем

предсказание на основе среднего по всем примерам, то значение Q может оказаться меньше 0.

σ^2 – коэффициент детерминации, равный отношению дисперсии предсказанных значений к дисперсии фактических, показывая, какая часть дисперсии предсказанных значений объясняется уравнением регрессии.

Средняя ошибка – усредненный по обработанным примерам модуль разности между предсказанным и фактическим значениями.

Максимальная ошибка – это максимальный модуль разности между предсказанным и фактическим значениями среди всех обработанных примеров.

% правильного предсказания знака изменения – это отношение числа примеров, для которых знак реального и предсказанного значения совпадают, и общего числа обработанных примеров, умноженное на 100.

Ниже с их помощью оценена эффективность нейросетевых предсказаний динамики фьючерсных котировок для SP, ED, DM. Результаты сведены в таблицу 1. Она состоит из трех блоков. Второй содержит статистику, относящуюся ко всем данным по трем временным рядам, а именно, к 1173 отсчетам для S&P500 и по 1170 отсчетов для марки ФРГ и евродоллара. Третий блок отражает статистику по рабочим множествам: из 77 отсчетов для S&P500 и 74 отсчетов для марки ФРГ и евродоллара.

Таблица. 1. Численные характеристики качества нейросетевого прогноза международных финансовых инструментов.

характеристика качества	Фьючерс на S&P500	Фьючерс на марку ФРГ	Фьючерс на евродоллар
Число эпох обучения	305	126	77
Время обучения (часов округленно)	19	41	19
Число примеров для обучения	1173	1170	1170
Коэффициент Q	0,74	0,80	0,75
Q^2	0,55	0,64	0,56
Средняя ошибка, %	0,182	0,196	0,179
Макс. Ошибка, %	2,17	2,29	2,28
% правильных предсказаний знака изменения	86	83	83
Число примеров для предсказаний	77	74	74
Коэффициент Q	0,80	0,32	0,58
Q^2	0,64	0,10	0,34
Средняя ошибка, %	0,21	0,79	0,20
Макс. Ошибка, %	0,79	9,10	4,61
% правильных предсказаний знака изменения	88	86	88

Мы видим, что из трех проанализированных фьючерсных котировок наилучшие предсказания достигаются на S&P500, наихудшие – на евродолларе, промежуточные – для марки ФРГ. Это следует из значений коэффициента Q на рабочем множестве (см. нижний блок табл. 1), хотя визуально на рис. 2а, 2б и 2с отличие в

качестве прогнозов заметить довольно трудно. Следует отметить, что несмотря на одинаковое качество обучения нейросети на SP, ED, DM (см. значения коэффициента Q в первом блоке табл.1), сеть обучалась на SP в 5 раз дольше, чем на DM, а на DM – в 4 раз дольше, чем на ED. Это, по-видимому, означает, что найти скрытые закономерности, содержащиеся во фьючерсных котировках на SP, значительно сложнее, чем соответствующие закономерности в DM и тем более в ED. В то же время, как отмечено выше, наилучшее качество прогноза достигается как раз на SP, а наихудшее - на ED. Все вместе это свидетельствует о том, что скрытые закономерности, обнаруженные нейросетью в SP, сохраняют свой характер на более длительных интервалах времени по сравнению с ED или, иными словами, фьючерсы на ED более подвержены смене внутренних закономерностей, что и приводит к наихудшему качеству прогноза.

IV Заключение

Таким образом, отражая современные тенденции в финансовом мире, междисциплинарный подход в экономике и финансах является прорывом в комбинировании различных методов теории сложности, таких, например, как методы нелинейной и хаотической динамики, мультифрактальный анализ и нейротехнологии. Интегральной задачей этого синтеза является дизайн, развитие и построения адаптивных интеллектуальных систем, помогающих практикам выигрывать в жесткой конкурентной среде.

Литература

- Ежов А.А., Шумский С.А. Нейрокомпьютинг и его применения в экономике и бизнесе (сер. Учебники экономико-аналитического института МИФИ / Под ред. проф. В.В. Харитонов). М., 1998.
- Arthur W. B., LeBaron B., Holland J. H., Palmer R., Tayler P. Asset Pricing Under Endogenous Expectations in an Artificial Stock Market, in The Economy as an Evolving Complex System II // Ed. by W. B. Arthur, S. Durlauf, D. Lane, Addison; Wesley, 1997.
- Bacry E., Delour J., Muzy J.F., A multifractal random walk, cond-mat/0005405, 2000
- Bacry E., Delour J., Muzy J.F., A multivariate multifractal model for return fluctuations, cond-mat/0009260, 2000

Baestaens D.E., Den Bergh W.-M.Van, Wood D. Neural network solutions for trading in financial markets. Pitman Publishing, 1994.

Calvet L., Fisher A., Mandelbrot B., Large deviations and the distribution of price changes, Cowles Foundation Discussion Paper \#1164, 1997.

Cassetti M.D. A neural network system for reliable trading signals, Stocks\&Commodities. 1993, Vol. 11, p. 261-266.

Cont R., Scaling and correlation in financial data, cond-mat/9705075, 1997

Demuth H., Beale M. Neural network toolbox for use with Matlab, 1997, Version 3.0, Users Guide, The Mathworks, Inc.

Davis A., Marshak A., Wiscombe W., Wavelet-based Multifractal analysis of non-stationary and/or intermittent geophysical signals, 1994, Wavelets in geophysics, Academic Press, 249-298

Fisher A, Calvet L., Mandelbrot B., Multifractality of Deutchemark// US dollar exchange rates, Cowles Foundation Discussion Paper \#1165, 1997

Feder J., Fractals, Plenum Press, 1988, 249 p.

Franses P.H., Time series models for business and economic forecasting, Cambridge University Press, 1998, 280 p.

Giles C.L., Lawrence S., Tsoi A.Ch., Rule inference for financial prediction using recurrent neural networks, Proceedings of IEEE/ IAFE Conference on computational intelligence for financial engineering IEEE, Piscataway. New York. 1997. P. 253-259

Grassberger P., Procaccia I., Characterization of strange attractors // Phys.Rev.Lett.48, 1983

Hecht-Nielsen R., Neurocomputing. Addison-Wesley Publishing Company, Inc., 1990.

Kantz H., Schreiber T., Nonlinear time series analysis, Cambridge University Press, 1997, 304 p.

Kean J., Chaos theory and neural network analysis, Stocks \&Commodities. 1992. Vol. 10. P. 251-253.

Kuo J.-M., Principe J.C., deVries B. Prediction of chaotic time series using recurrent neural networks // IEEE Workshop NN for SP, 1992.

Lapedes A., Farber R.. Nonlinear signal processing using neural networks: prediction and system modelling, technical report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM, 1987.

LeBaron B. A Fast Algorithm for the BDS Statistic // Studies in Nonlinear Dynamics and Econometrics, 2, 1997. Vol.2. P. 53-59.

LeBaron B., Brock W. A, Dechert W. D., and. Scheinkman J. A. Test for Independence Based on the Correlation Dimension // Econometric Reviews. 1996. №15. P. 197-235.

LeBaron B., Chaos and Nonlinear Forecastability in Economics and

Finance // Philosophical Transactions of the Royal Society of London. 1994. Vol.348. P. 397-404.

Mandelbrot B., A Class of Multinomial Multifractal Measures with Negative (Latent) Values for the "Dimension" $f()$, in Fractals' Physical Origins and Properties, Proc. of the Erice Meeting (Ed. L.Pietronero), N.Y. Plenum Press, 1988, 3--29.

Mandelbrot B., Negative Dimensions and Holders Multifractals and their Holder Spectra, and the Role of Lateral Preasymptotics in Science // J.Fourier Analysis (Special J.P. Kahane Issue), 1995, 409-432.

Mandelbrot B.B., Fractals and scaling in finance, Springer, 1997, 551 p.

Mandelbrot B., Fisher A., Calvet L., A multifractal model of asset returns, Cowles Foundation Discussion Paper №1164, 1997

Mantegna R.N., Stanley H.E. An introduction to econophysics. Correlations and complexity in finance. Cambridge University Press. 2000.

Mills T.C., The econometric modelling of financial time series, Cambridge University Press, 1993, 247 p.

Muzy J.F., Bacry E., Delour J., Modelling fluctuations of financial time series: from cascade process to stochastic volatility, cond-mat/0005400, 2000

Peters E.E. Chaos and Order in Capital Market, John Wiley&Sons. 1996.

Poddig Th. Short Term Forecasting of the USD/DM-Exchange Rate, Proceedings of the first International Workshop on Neural Networks in the Capital Markets / Ed. by A. N. Refenes. London Business School. London. 1993.

Poddig Th., Rehugler H. A World Model of Integrated Financial Markets using Artificial Neural Networks // Journal of Neurocomputing. 1996. № 10. P. 251-273

Poddig Th. Developing Forecasting Models for Integrated Financial Markets using Artificial Neural Networks // Neural Network World. 1998. №1. P. 65 – 80.

Schuster H.G., Deterministic Chaos, Physik-Verlag, Weinheim, 1984

Torrence Ch., Compo G. P., A practical guide to wavelet analysis // 1998, Bulletin of the American Meteorological Society, Vol. 79, No. 1, 61-78

Wolf A., Swift J.B., Swinney H.L., Vastano J.A., Determining Lyapunov exponents from a time series // Physica 16D, N3, 1985

Дмитриева Людмила Анатольевна, кандидат физ.-мат. наук,

старший преподаватель, кафедры математической физики,
физический факультет, СПбГУ, e-mail: [HYPERLINK
mailto:mila@JK1454.spb.edu mila@JK1454.spb.edu](mailto:HYPERLINKmailto:mila@JK1454.spb.edu)

Юрий Александрович Куперин, доктор физ.-мат. наук,
профессор, физический факультет СПбГУ и факультет
менеджмента СПбГУ, e-mail: [HYPERLINK
mailto:kuperin@JK1454.spb.edu kuperin@JK1454.spb.edu](mailto:HYPERLINKmailto:kuperin@JK1454.spb.edu)

Сорока Ирина Владимировна, магистр физики, технический
аналитик, Балтийское финансовое агентство

COMPLEX SYSTEMS THEORY METHODS IN ECONOMICS AND FINANCE

L.A.Dmitrieva, Yu.A.Kuperin, I.V.Soroka

The key concepts of the traditional management models and analytical methods have become or will soon be ineffective. As the rate of change in the financial world continues to accelerate, a new synthesis of analytical and computational approaches is required. This new synthesis is Complexity. Complexity Science is the study of dynamic processes in complex, interacting, adapting systems. The rules that govern complex adaptive systems are very different from those of equilibrium systems. They provide the powerful tools to analyse, understand and implement the opportunities available in today's complex financial world. By understanding modern tendencies in financial world, interdisciplinary approach advanced in combining different methods of complexity such as methods of nonlinear and chaotic dynamics, multifractal analysis and neural networks technology.

Dmitrieva Ludmila Anatol'evna, Ph.D. (Physics), senior lecturer,
Department of Physics, St.Petersburg State University, e-mail:
[HYPERLINK mailto:mila@JK1454.spb.edu mila@JK1454.spb.edu](mailto:HYPERLINKmailto:mila@JK1454.spb.edu)
Kuperin Yuri Aleksandrovich, Doctor of Sciences (Physics),
professor, Department of Physics and School of Management,
St.Petersburg State University, e-mail: [HYPERLINK
mailto:kuperin@JK1454.spb.edu kuperin@JK1454.spb.edu](mailto:HYPERLINKmailto:kuperin@JK1454.spb.edu)
Soroka Irina Vladimirovna, M.Sc. (Physics), technical analyst, Baltic
Financial Agency,
e-mail: [HYPERLINK mailto:phosphor@ok.ru phosphor@ok.ru](mailto:HYPERLINKmailto:phosphor@ok.ru)

Всероссийской научно-методической конференции. Санкт-Петербург, 11-13 октября 2001г.-СПб., 2001, стр.29-50